

基于神经网络的泡沫混凝土强度及导热性能预测

尹冠生,傅 沉,贺燕飞
(长安大学 理学院,陕西 西安 710061)

摘要:基于神经网络原理,建立预测泡沫混凝土性能的 BP 神经网络模型,期望通过输入配合比主要参数,得到泡沫混凝土强度及导热性能的预测结果。将实验数据分为训练组和对照组,对训练组进行非线性拟合,若拟合结果满足误差精度则模型建立完毕;通过拟合结果与对照组的比较,可验证模型预测精度。结果表明,BP 神经网络模型能够准确拟合实验数据,利用其泛化能力进行预测的结果与对照组的误差小于 8%,该模型具有很高的预测精度。

关键词:BP 神经网络;泡沫混凝土;抗压强度;导热性能;预测

中图分类号:TU528.2 **文献标识码:**A **文章编号:**1671-5322(2016)02-0049-06

随着我国墙体材料技术革新、建筑节能政策不断推行,被动式低能耗建筑材料结构研究领域提出愈来愈多的问题。泡沫混凝土作为一种新型环保轻质材料,由于良好的隔热、隔音性能,在外墙保温节能领域被广泛应用。但由于泡沫混凝土强度低、干缩值大以及吸水率高等不足,阻碍了其应用及推广。

泡沫混凝土强度受多种因素的影响,如:干密度、孔隙、原材料以及养护方式等,其中干密度是影响强度的主要因素,两者呈线性关系,强度会随着干密度的增大而提升^[1]。朱明等^[2]研究了泡沫混凝土孔结构与导热性能的关系,得出了随着干密度的增加,导热系数增大,保温能力降低的结论。所以泡沫混凝土强度越高,其隔热、隔音性能越差,强度与导热性能间的关系是非线性的。

目前,已经建立了多种泡沫混凝土强度预测模型,如:“强度—配合比”模型、“强度—孔隙”模型和“强度—孔胶比”模型等^[3]。为达到预测泡沫混凝土强度等性能的目的,常采用实验分析和数学建模等方法^[4]。尽管已经提出许多配方和规范,但迄今为止仍没有文献表明有了公认的泡沫混凝土的配合比标准^[5]。泡沫混凝土由于需

要考虑发泡剂等因素,不能采用普通混凝土的理论及材料配比经验公式。为此,朱红英^[6]通过设计正交实验的方法完成了泡沫混凝土单因素与多因素的配合比设计实验,建立了相关参数的线性回归方程。

本文利用 BP 神经网络模型,通过模型的自主训练对泡沫混凝土性能进行预测;通过重新训练神经网络,满足多种工况的配合比设计要求。

1 BP 神经网络原理

1.1 BP 神经网络概述

BP 神经网络算法的实质是一种最速下降法,理论上只要模型中隐含层的神经元数量合适,通过多次训练,神经网络模型就能够模拟任意的非线性映射关系。

BP 神经网络主要由两部分组成:信号的正向传递和误差的反向传递。输入参数通过输入层经过隐含层传递至输出层,单层神经元的输出状态即是下一层神经元的输入状态,此过程为信号的正向传递。当输出层与期望输出比较不满足预设精度时,进入误差的反向传递过程。通过网络路径反向逐层对神经元权值和阈值在误差函数斜率

收稿日期:2016-03-15

基金项目:教育部博士点基金项目(20130205110014);陕西省自然科学基金项目(2014JM1005);陕西省住房和城乡建设厅项目(陕建科函[2015]19号)

作者简介:尹冠生(1958—),男,河北石家庄人,教授,博士,主要研究方向为力学。

下降的方向上进行调整,从而逼近期望的输出,完成对神经网络的训练过程。BP 神经网络的拓扑

结构如图 1 所示。




图 1 BP 神经网络拓扑结构
Fig.1 BP neural network topology

图 1 中, $P_1, P_2, \dots, P_i$ 是 BP 神经网络的输入值, $a2_1, a2_2, \dots, a2_k$ 是 BP 神经网络的预测值, ω_{ij} 和 ω_{jk} 为 BP 神经网络权值, $b1_j$ 和 $b2_k$ 为 BP 神经网络阈值。由图 1 可以看出 BP 神经网络类似于一个函数系统,其输入参数和输出参数即函数的自变量和因变量。即假设一个 BP 神经网络的输入层节点数共 i 个,输出层节点数共 k 个,这个 BP 神经网络模型就模拟了从 i 个自变量到 k 个因变量的非线性函数映射关系。

1.2 单一神经元模型

神经元细胞一般由细胞体、树突、轴突组成,其中树突负责接收输入信号,细胞体负责处理信号,轴突将处理后的信号传递给下一个神经元。

神经元模型就是对上述生物模型进行模仿、抽象的成果。神经元的输出不但受上层神经元信号的影响,而且也受其内部其他因素的影响,所以在建模时额外添加一个阈值 b ,模拟其内部对神经元产生的影响。一个具有 r 个输入节点的神经元如图 2 所示。

输入分量 p_i ($i = 1, 2, \dots, r$) 与权值分量 ω_i ($i = 1, 2, \dots, r$) 相乘,以 $\sum_{i=1}^r \omega_i p_i$ 的形式求和后,作为激活函数 $f(\cdot)$ 的输入,阈值 b 作为神经元的另一个输入。




图 2 单个神经元模型图
Fig.2 Single neuron model

神经元模型的输出可表示为^[7]:

$$A = f(\sum_{i=1}^r \omega_i p_i + b) \tag{1}$$

阈值的本质是一种特殊的权值,该权值对应的输入始终为常数 1。添加阈值是为了使激活函数图像可以左右移动,增加解决问题的可能性。

激活函数 $f(\cdot)$ 是神经网络的核心,其基本作用是:

- (1) 控制输入对输出的激活作用;
- (2) 对输入、输出进行函数转换;
- (3) 将可能无限域的输入变换成有限域内的

输出。

本文中的 $f_1(\cdot)$ 取S型函数(logsig函数)

$$A = f(n) = \frac{1}{1 + e^{-n}} \quad (2)$$

$f_2(\cdot)$ 取线性函数(purelin函数)

$$A = f(n) = n \quad (3)$$

还有阈值型激活函数

$$A = f(n) = \begin{cases} 1, n \geq 0 \\ 0, n < 0 \end{cases} \quad (4)$$

1.3 BP神经网络程序流程

BP神经网络只有通过训练过程,才可以具有联想记忆和预测能力。以下是BP神经网络训练过程的具体步骤^[8],训练流程图见图3。




图3 网络训练流程图

Fig.3 Network training flow chart

(1)网络初始化。根据输入和输出数据,确定输入层节点数 i 、隐含层节点数 j 和输出层节点数 k 。随机初始化输入层、隐含层和输出层神经元之间的权值 ω_{ij} 、 ω_{jk} ,隐含层阈值 b_1 ,输出层阈值 b_2 ,设置给定的学习速率和神经元激励函数。

(2)隐含层输出计算。根据输入变量 P ,输入层和隐含层间的权值 ω_{ij} 以及隐含层阈值 b_1 ,计算隐含层输出 a_1 。

$$a_{1j} = f_1\left(\sum_{i=1}^r \omega_{ij}p_i + b_{1j}\right) \quad (j = 1, 2, \dots, s_1) \quad (5)$$

(3)输出层输出计算。根据隐含层输出 a_1 ,隐含层和输出层之间的权值 ω_{jk} 和阈值 b_2 ,计算输出层的输出 a_2 。

$$a_{2k} = f_2\left(\sum_{j=1}^{s_1} \omega_{jk}a_{1j} + b_{2k}\right) \quad (k = 1, 2, \dots, s_2) \quad (6)$$

(4)误差计算。根据输出层输出的 a_2 和期望输出比较,计算网络误差 e 。

$$e_k = t_k - a_{2k} \quad (7)$$

(5)权值更新。根据网络误差 e 更新网络连接权值 ω_{ij}^* 、 ω_{jk}^* 。

$$\omega_{ij}^* = \omega_{ij} + \eta a_{1j}(1 - a_{1j})p_i \sum_{k=1}^{s_2} \omega_{jk}e_k \quad (i = 1, 2, \dots, r) \quad (j = 1, 2, \dots, s_1) \quad (8)$$

$$\omega_{jk}^* = \omega_{jk} + \eta a_{1j}e_k \quad (j = 1, 2, \dots, s_1) \quad (k = 1, 2, \dots, s_2) \quad (9)$$

(6)阈值更新。根据网络误差 e 更新隐含层和输出层节点阈值 b_1, b_2 。

$$b_{1j}^* = b_{1j} + \eta a_{1j}(1 - a_{1j}) \sum_{k=1}^{s_2} \omega_{jk}e_k \quad (j = 1, 2, \dots, s_1) \quad (10)$$

$$b_{2k}^* = b_{2k} + \eta e_k \quad (k = 1, 2, \dots, s_2) \quad (11)$$

(7)判断算法迭代是否结束,若没有结束,返回步骤(2)。

2 实例分析

2.1 实验数据分析

本文引用文献[2]所使用的实验数据作为神经网络算法学习的对象,其中抗压强度与导热性能的测试方法如下:

(1)抗压强度测试

成型试件尺寸 $70.7 \text{ mm} \times 70.7 \text{ mm} \times 70.7 \text{ mm}$,养护环境湿度95%、温度 $(20 \pm 1)^\circ\text{C}$,成型后带模养护24 h,到达预定养护龄期28 d,取出试件置入 $60^\circ\text{C} \sim 65^\circ\text{C}$ 烘箱内连续烘至恒重,置入干燥皿中冷却后,采用电子天平称量其质量,计算出容重,然后测定试件的抗压强度。

(2)导热系数测试

泡沫混凝土导热系数的测试,参照文献[9],采用DRCDD-3030型智能化导热系数测定仪测出其导热系数。试样的成型尺寸为 $300 \text{ mm} \times 300 \text{ mm} \times 30 \text{ mm}$,养护3 d后脱模,置于标准养护室至规定龄期后烘干,测定导热系数。

本文从12组实验数据中随机抽取3号、9号两组作为对照样本,剩余十组作为训练样本。每组数据包含6个参数:4个配合比参数即水泥、粉煤灰、水、发泡剂使用量,2个泡沫混凝土性能参数即抗压强度、导热系数。将配合比参数以向量形式输入,通过神经网络模型输出抗压强度和导热系数,与样本对比后重新调整神经网络内部的权值,直至到达预设精度。具体数据如表1所示。

表 1 不同配合比泡沫混凝土的抗压强度和导热系数

Table 1 Compression strength and thermal conductivity of foamed concrete with different mix proportion

样品号	配合比设计				抗压强度/ MPa	导热系数/ [W · (m · K) ⁻¹]
	水泥/g	粉煤灰/g	水/g	发泡剂/g		
1	800	200	360	0	49.9	0.213
2	800	200	360	2.7	3.82	0.098
3	800	200	360	5.4	1.24	0.066
4	800	200	360	8.1	0.41	0.054
5	650	350	380	0	48.8	0.201
6	650	350	380	2.7	3.39	0.095
7	650	350	380	5.4	0.97	0.061
8	650	350	380	8.1	0.39	0.046
9	500	500	400	0	47.3	0.196
10	500	500	400	2.7	2.58	0.093
11	500	500	400	5.4	0.70	0.057
12	500	500	400	8.1	0.34	0.043

2.2 网络设计

通过 MATLAB 的 rand 函数,随机选择 10 组训练组数据和 2 组对照组数据。在每次输入数据之前,都利用 mapminmax 函数将数据归一化处理。

$$y = f(x) = (y_{\max} - y_{\min}) \times \frac{x - x_{\min}}{x_{\max} - x_{\min}} + y_{\min}$$

(12)

式中 $y_{\min} = -1, y_{\max} = 1, x_{\min}$ 与 $x_{\max}$ 分别为原始数据的最小值和最大值。

经过归一化处理后的数据,是一个域为 $[-1,1]$ 的数据集合。

归一化函数可以消除不同维度数据间数量级上的差别,避免由于各维数据数量级上的差别所带来的网络预测误差。

BP 神经网络构建,采用 MATLAB 神经网络工具箱的 newff 函数。对网络参数进行初始化,隐含层数量设置为 5、隐含层激活函数设置为 ‘logsig’、输出层激活函数设置为 ‘purelin’、学习函数设置为 ‘trainlm’。本文期望误差设置为 0.000 1、学习速率设置为 0.001、最大训练次数设置为 10 000。

利用 train 函数对已构建的 BP 神经网络进行训练。将待预测数据进行归一化,利用 sim 函数得到预测输出;最后将输出反归一化,与实测数据比较求出误差。

2.3 实验结果分析

2.3.1 网络设计和训练分析

网络训练过程误差曲线和回归分析分别如图 4、图 5 所示。




图 4 BP 网络训练过程误差曲线

Fig. 4 Error curve of BP network training process




图 5 BP 网络回归分析

Fig. 5 Analysis of BP neural network regression

从图 4 可以看出,Levenberg-Marquardt 算法收敛速度较快,在运行第 7 迭代步时,满足误差精度;从图 5 可以看出,BP 网络的模拟精度较高,所以本文所选择的隐含层数量($j=5$)和激活函数($f_1(\cdot)$ 取 logsig 函数 $f_2(\cdot)$ 取 purelin 函数)是合适的。表 2 给出 BP 神经网络训练完成后对训

练样本的拟合结果。
2.3.2 网络预测结果分析
将训练完成的网络输入预测样本中的配合比,可以得到 BP 神经网络对预测样本的抗压强度及导热性能的预测值。预测结果如表 3 所示。

表 2 拟合结果
Table 2 Fitting result

组号	拟合值		实际值		误差值	
	抗压强度/ MPa	导热系数/ [W · (m · K) ⁻¹]	抗压强度/ MPa	导热系数/ [W · (m · K) ⁻¹]	抗压强度/ MPa	导热系数/ [W · (m · K) ⁻¹]
1	50.049 9	0.213 2	49.900 0	0.213 0	0.149 9	0.001 0
2	4.121 5	0.098 5	3.820 0	0.098 0	0.301 5	0.000 5
4	0.362 0	0.053 8	0.410 0	0.054 0	-0.048 0	-0.000 2
5	49.272 6	0.202 1	48.800 0	0.201 0	0.472 6	0.001 1
6	3.652 8	0.095 8	3.390 0	0.095 0	0.262 8	0.000 8
7	0.892 6	0.061 2	0.970 0	0.061 0	-0.077 4	0.000 2
8	0.342 5	0.046 4	0.390 0	0.046 0	-0.047 5	0.000 4
10	3.227 3	0.094 0	2.580 0	0.093 0	0.647 3	0.001 0
11	0.759 3	0.057 3	0.700 0	0.057 0	0.059 3	0.000 3
12	0.313 0	0.043 5	0.340 0	0.043 0	-0.027 0	0.000 5

由表 3 可以看出,两个预测样本的总体误差都小于 8%,且 3 号样本的误差与 9 号样本相比明显较大。经过分析 3 号样本误差较大可能有以下原因:

- (1) 实验数据的预处理过程不够完善;
- (2) 训练精度的设定较低;

- (3) 神经网络模型存在一定误差。
- 针对以上问题,本文提出可能的解决方法:
- (1) 对实验数据进行样本优化,保证训练数据的有效性;
- (2) 选择合适的训练精度和激活函数;

表 3 预测结果分析
Table 3 Analysis of Forecast result

		实际值/ MPa	BP 网络输出值/ MPa	绝对误差/ MPa	相对误差/ %
3 号	抗压强度/MPa	1.240 0	1.153 1	-0.086 9	7.008 1
	导热系数/[W · (m · K) ⁻¹]	0.066 0	0.061 5	-0.004 5	6.818 2
9 号	抗压强度/MPa	47.300 0	48.338 2	1.038 2	2.194 9
	导热系数/[W · (m · K) ⁻¹]	0.196 0	0.200 2	0.004 2	2.142 8

(3) 运用其他优化算法优化 BP 神经网络的训练过程。

3 结语

- (1) 利用 MATLAB 提供的神经网络工具箱,建立 BP 神经网络模型,完成对泡沫混凝土的抗压强度和导热性能的预测工作。
- (2) 通过网络训练过程误差曲线图和 BP 网

络回归分析图,验证了选取相关函数和学习算法的合理性。
(3) 对预测结果进行分析,结果与实际值较为接近,9 号对照组相对误差不大于 3%,3 号对照组相对误差不大于 8%,总体平均相对误差为 4.541%。因此 BP 神经网络可有效应用于泡沫混凝土抗压强度和导热性能的预测,在工程实践中具有很广阔的应用前景。

(4) 在进一步研究中,可结合其他优化算法, 的准确性和泛化能力。
对未训练数据进行样本优化,提升 BP 神经网络

参考文献:

[1] 张萌,田清波,徐丽娜,等. 发泡水泥的研究现状及展望[J]. 硅酸盐通报,2014,33(10):2 547-2 551.
[2] 朱明,王方刚,张旭龙,等. 泡沫混凝土孔结构与导热性能的关系研究[J]. 武汉理工大学学报,2013,35(3):20-25.
[3] NAMBIAR E K K, RAMAMURTHY K. Models for strength prediction of foam concrete[J]. Materials and Structures,2008, 41(2):247-254.
[4] 郭向勇,郭建立. 泡沫混凝土性能研究进展[J]. 工程质量,2013,31(4):17-23.
[5] 任先艳,张玉荣,刘才林,等. 泡沫混凝土的研究现状与展望[J]. 混凝土,2011(2):139-141,144.
[6] 朱红英. 泡沫混凝土配合比设计及性能研究[D]. 西安:西北农林科技大学,2013.
[7] 丛爽. 面向 MATLAB 工具箱的神经网络理论与应用[M]. 3 版. 合肥:中国科学技术大学出版社,2009:8-68.
[8] 王小川. MATLAB 神经网络 43 个案例分析[M]. 北京:北京航空航天大学出版社,2013:1-2.
[9] 中华人民共和国国家质量监督检验检疫总局,中国国家标准化管理委员会. 绝热材料稳态热阻及有关特性的测定防护热板法 GB/T 10294—2008[S]. 北京:中国标准出版社,2009.

Prediction of Foamed Concrete Compression Strength and Thermal Conductivity Based on BP Neural Network

YIN Guansheng, FU Chen, HE Yanfei
(College of Science, Changán University, Xián Shaanxi 710061, China)

Abstract:In this paper, BP neural network model is used to predict the compression strength and thermal conductivity of the foamed concrete. The experimental data were divided into training dataset and control dataset. On the training dataset, the proposed BP? neural? network? model was applied. The fitted model was obtained by tuning the parameters of mixing proportion with error rate controlled at pre – defined level. The prediction accuracy of the model was verified by comparing the results of the fitted model on the control dataset with true values. The results show that the predicted error rate is less than 8% , indicating that BP neural network is capable of predicting the experimental data accurately.
Keywords:BP neural network; foamed concrete; compression strength; thermal conductivity; prediction

(责任编辑:张英健)